

DISEÑO DE UN SISTEMA DE RECONOCIMIENTO DE ROSTROS MEDIANTE LA HIBRIDACIÓN DE TÉCNICAS DE RECONOCIMIENTO DE PATRONES, VISIÓN ARTIFICIAL E IA, ENFOCADO A LA SEGURIDAD E INTERACCIÓN ROBÓTICA SOCIAL

DESIGN OF A FACE RECOGNITION SYSTEM USING THE HYBRIDISATION PATTERN RECOGNITION TECHNIQUE, AND VISION IA, FOCUSED ON ROBOTICS SAFETY AND SOCIAL INTERACTION

Noviembre
2013

Edición 6

Pág. 16 -28

Autores

Oscar Eduardo Gualdrón¹, Oscar Manuel Duque Suárez², Mauricio Anastasio Chacón Rojas³

Resumen

Este artículo presenta el diseño, desarrollo y la implementación de desarrollo de un sistema de reconocimiento de rostros mediante la hibridación de técnicas de reconocimientos de patrones, visión artificial e inteligencia artificial. La presente investigación recopila el producto de la unión de las técnicas de visión artificial y las técnicas de inteligencia artificial y sus implicaciones en múltiples aplicaciones tales como el control de robots de interacción social.

Palabras clave:

ICA, modelos activos, PCA, redes neuronales, robots de interacción social.

Abstract

This article presents the design, development and implementation of developing a face recognition system using hybridization pattern recognition techniques, computer vision and artificial intelligence. This research collects the union of artificial vision techniques and artificial intelligence techniques and their implications in many applications such as robot control social interaction.

Keywords:

Active models, ICA, PCA, neural networks, robots of social interaction.

1. Doctor en Ingeniería Electrónica, Ingeniero Electrónico, Facultad de Ingenierías y Arquitectura, Universidad de Pamplona, Norte de Santander, Colombia, eduardooscar@hotmail.com, oscar.gualdron@unipamplona.edu.co
2. Ingeniero Mecatrónico, Mg. Controles Industriales, Facultad de Ingenierías y Arquitectura, Universidad de Pamplona, Norte de Santander, Colombia, omduke@hotmail.com
3. Ingeniero Mecatrónico, Universidad de Pamplona, ingmecatronico_mchr@hotmail.com

DISEÑO DE UN SISTEMA DE RECONOCIMIENTO DE ROSTROS MEDIANTE LA HIBRIDACIÓN DE TÉCNICAS DE RECONOCIMIENTO DE PATRONES, VISIÓN ARTIFICIAL E IA, ENFOCADO A LA SEGURIDAD E INTERACCIÓN ROBÓTICA SOCIAL

Introducción

La revolución tecnológica actual y el interés multidisciplinar en desarrollar metodologías y productos que mejoren los resultados obtenidos en el reconocimiento de patrones en su aplicación en el reconocimiento y clasificación de características de rostros y de esta manera perfeccionar la emulación del reconocimiento de rostros propios de los seres humanos a fin de ser incorporados en múltiples aplicaciones tales como la interacción robótica social y la seguridad; entre otras.

Ahora bien, nuestra intención en esta publicación es dar a conocer el resultado de la investigación para el desarrollo de un sistema de reconocimiento de rostros mediante la hibridación de técnicas de reconocimientos de patrones, visión artificial e inteligencia artificial.

El artículo siguiente contempla el diseño e implementación del sistema de reconocimiento de rostros y de características tales como el género, el diseño, técnicas implementadas y metodología aplicadas al sistema y lo concerniente a las aplicaciones en las que puede tener relevancia el sistema desarrollado enfocándonos en el control de robots de interacción social.

MODELOS ACTIVOS Y SU APLICACIÓN EN EL PROYECTO

Los modelos activos es un método para realizar la ubicación de puntos de interés


con los cuales puede establecerse un modelo estadístico, los modelos activos como es el caso del algoritmo de ASM incluyen dos rutinas, la construcción del modelo y búsqueda. Para nuestra aplicación en la cual el objetivo es el reconocimiento usaremos los métodos activos a fin establecer los puntos de interés y el modelo de manera que podamos usar el modelo para entrenar un clasificador inteligente con redes neuronales para realizar el reconocimiento y la clasificación. El procedimiento de construcción de modelos de ASM requiere marcar k puntos clave de las características faciales de cada imagen de la cara en el conjunto de entrenamiento [1].

UBICACIÓN DE PUNTOS EN EL ROSTRO

A fin de realizar la ubicación de los puntos característicos en el rostro usamos Active Shape Model (ASM) que como método activo que genera un modelo de los patrones y características que se pretenda determinar. Este método para la determinación del modelo está determinado por la serie de puntos de modelo, así como la interconexión entre los puntos. La adecuación o acondicionamiento se ejecuta utilizando los bordes de imagen previa búsqueda y establecimiento de los mismos.

En la figura 1 se representa los puntos ubicados por la utilización del método ASM, estos puntos se ubican según unas estadísticas que suministra el algoritmo [2].

Figura 1. Puntos seleccionados del modelo inicial



Fuente: propia

METODO DE HARRIS PARA LA DETECCION DE BORDES

Como habíamos explicado anteriormente para la determinación de los puntos propios del modelo del método ASM requerimos establecer los bordes para que mediante la aplicación de la técnica se puedan determinar los puntos, para ello se ha decidido usar el método de Harris.

DESARROLLO MATEMÁTICO DEL METODO DE HARRIS

Para determinar las transiciones de las regiones de grises, todos los pequeños cambios posibles pueden ser cubiertos llevando cabo una expansión analítica sobre el origen del cambio. [3], como se muestra en la ecuación (1) y (2).

$$E_{x,y} = \sum_{u,v} W_{u,v} [I_{x+u,y+v} - I_{u,v}]^2 \quad (1)$$

Donde,

$W_{u,v}$ = Función de ventana

$I_{x+u,y+v}$ = Cambio de intensidad

$I_{u,v}$ = Intensidad

$W_{u,v}$ = Función de ventana

$$E_{x,y} = \sum_{u,v} W_{u,v} [xX + yY + O(x^2, y^2)]^2 \quad (2)$$

UBICACIÓN Y DETECCION DE OJOS

Los ojos en la generación del modelo del rostro se constituyen en puntos estratégicos para lograr dicho objetivo. La detección de ojos en imágenes del rostro es muy importante para un vasto número de aplicaciones que van desde el reconocimiento facial para seguimiento de mirada. Los estudios ejecutados con base de este método dan como eficaz la utilización del método. [4]

El Modelo de color de la piel es el modelo matemático que describe la distribución de colores de piel. Un espacio o región de color adecuado debe ser elegido antes de formular modelos de color de piel.

La idea es lograr un mejor espacio para trabajar las imágenes a color es *GLHS* ya que este modelo de color responde efectivamente frente a los diferentes tipos de piel. El proceso de *GLHS* se ve representado por las siguientes ecuaciones.

$$\min(c) = \min(R, G, B) / 255$$

$$\text{med}(c) = \text{med}(R, G, B) / 255 \quad (3)$$

$$\max(c) = \max(R, G, B) / 255$$

Por lo tanto la luminosidad, el tono y la saturación se pueden calcular:

$$h(c) = k(c) + f(c) \quad (4)$$

Donde $k(c)$ indica el número de secuencia y $f(c)$ se utiliza para calcular el ángulo.

$$k(c) = \begin{cases} 0 : R > G \geq B \\ 1 : G \geq R > B \\ 2 : G > B \geq R \\ 3 : B \geq G > R \\ 4 : B > R \geq G \\ 5 : R \geq B > G \end{cases} \quad (5)$$

$$f(c) = \begin{cases} \frac{\text{med}(c) - \min(c)}{\max(c) - \min(c)} : k(c) \\ \frac{\max(c) - \text{med}(c)}{\max(c) - \min(c)} : k(c) \end{cases} \quad (6)$$

Luminosidad,

$$l(c) = (\max(c) - \text{med}(c)) - (\text{med}(c) - \min(c)) \quad (7)$$

Saturación,

$$s(c) = \frac{1}{3}(\max(c) - \min(c)) + \frac{1}{3}(\text{med}(c) - \min(c)) \quad (8)$$

ANÁLISIS DE COMPONENTES PRINCIPALES (ACP Ó PCA)

Las técnicas de análisis de datos por mecanismos estadísticos proveen la virtud de ser propicias para las tareas de reconocimiento y de clasificación, debido a los manejos de dimensionalidad con los que permiten trabajar mejorando los procesos de reconocimiento.

Se parte de una matriz U la cual contiene a los sujetos descritos por (j) y las variables de cada uno de ellos estarán descritas por (i) conformando una matriz de $i \times j$:

$$U = \begin{bmatrix} u_{11} & \cdots & u_{1j} \\ \vdots & \ddots & \vdots \\ u_{i1} & \cdots & u_{ij} \end{bmatrix} \quad (9)$$

Por tanto esta matriz U se puede transformar en una nueva matriz D de distancias, debido a los puntos que forman los datos de los usuarios en j -dimensional, con las mismas dimensiones $i \times j$.

$$D = \begin{bmatrix} d_{11} & \cdots & d_{1j} \\ \vdots & \ddots & \vdots \\ d_{i1} & \cdots & d_{ij} \end{bmatrix} \quad (10)$$

Considerando que la matriz D parte de la matriz U , Cada línea de (D) corresponde a los componentes de cada punto de (U) .

Ahora encontramos que para poder relacionar (U) con (D) , se crea una nueva matriz M como matriz de paso de (U) , esta matriz será de tamaño $j \times j$ con sus componentes de la siguiente manera:

$$\begin{aligned} m_1 &= m_{11}u_1 + \cdots + m_{k1}u_k \\ m_2 &= m_{12}u_1 + \cdots + m_{k2}u_k \\ &\vdots \\ m_k &= m_{1k}u_1 + \cdots + m_{kk}u_k \end{aligned} \quad (11)$$

Dando como resultado la matriz M :

$$M = \begin{bmatrix} m_{11} & \cdots & m_{1j} \\ \vdots & \ddots & \vdots \\ m_{j1} & \cdots & m_{jj} \end{bmatrix} \quad (12)$$

De tal manera encontramos que la relación entre U , D y M es.

$$U = D * M^T \quad (13)$$

MATRIZ DE COVARIANZA

Para determinar la matriz de covarianza de la matriz U la vemos representada por:


$$C = \begin{bmatrix} c^2_{u_1} & \cdots & c_{u_1u_j} \\ \vdots & \ddots & \vdots \\ c_{u_1u_j} & \cdots & c^2_{u_j} \end{bmatrix} \quad (14)$$

Donde $c^2_{u_i}$ representa la varianza de la variable de U_i en el conjunto y, $c_{u_iu_j}$ es la covarianza U_i y U_j .

CREACIÓN DE SUBESPACIO (ESPACIO DE IMAGEN)

Los vectores que representan a los rostros pertenecen a un espacio, el que se denomina sub-espacio o espacio de imagen, es allí donde se encuentran las imágenes con dimensión n . ver figura 2.

Figura 2. Sub espacio de las imágenes



Fuente: propia

Al utilizar Análisis de componentes principales obtenemos los factores o componentes del sub-espacio. Reduciendo la dimensión del conjunto o espacio y mejorando los patrones típicos del conjunto en general.

EIGENFACES

En su trabajo pionero en 1991, Kirby y Sirovich, propuso el uso de PCA para el análisis y la representación de la cara. Su trabajo fue seguido por la técnica "Eigenfaces" de Turk y Pentland, la aplicación de la ACP para reconocimiento facial. Puesto que los vectores son basados en PCA había la misma dimensión que las imágenes de entrada de la cara, que se denomina "Eigenfaces". La Figura 3 muestra un ejemplo de la cara media y algunos de los Eigenfaces [5].

Figura 1. Eigenfaces, la cara media de la izquierda, seguido de 7 eigenfaces.




Fuente: propia

Una eigenface es la combinación de una combinación de componentes o bases de unas series de caras, a estos rostros bases se les conoce como Eigenfaces.

RED NEURONAL BACKPROPAGATION

La red neuronal backpropagation se encuentra dentro del grupo de red de aprendizaje supervisado el cual trabajan bajo un gradiente descendiente, donde el patrón de entrada se propaga por toda la red hasta la salida, así mismo las salidas de error se propagan hacia la capa anterior de neuronas. Bajo esta estructura neuronal se desarrolló el clasificador inteligente. El error que genera en función a sus pesos es una superficie de n dimensiones, la cual al evaluar el gradiente se obtiene la dirección en la parte de mayor crecimiento, por lo tanto se toma esta dirección pero negativa para minimizar el error. [6]. El tipo de arquitectura de la red backpropagation se observa en la figura 4.

Figura 2. Arquitectura RED Backpropagation



Fuente: propia

CARACTERISTICAS DE CAPTURA DE LA IMAGEN


Tamaño de la imagen

La imagen de un rostro se representa utilizando un matriz, en nuestro caso la imagen tiene unas dimensiones de (180 * 200) pixeles, donde (x = 180) y (y = 200), y al ser en RGB tendremos componentes por color, dado que conocemos el ancho y alto de la imagen el número de pixeles que obtendremos será el producto entre ((x*y) *3).

Adecuación de la imagen

Ya obtenida la imagen del usuario se procede a aplicarle el método de Harris (detección de bordes). Para extraer de la imagen tratada con el método de detección de Harris, ver figura 5-a, la silueta del usuario se escoge los puntos que delimitan la figura de usuario y así obtener una imagen más limpia como se muestra en la figura 5-b y a partir de esta trabajar en el reconocimiento e identificación.

Figura 3. (a) Aplicación del método, (b). Imagen resultante del procesamiento



Fuente: propia

ALGORITMO UTILIZADO PARA LA IDENTIFICACION DEL USUARIO POR MEDIO DE ANALISIS DE COMPONENTES PRINCIPALES (ACP)

Como se mencionó anteriormente las características de las imágenes de los usuarios y el respectivo tratamiento. Una vez se tiene la matriz de usuarios que está conformada de cada vector columna de la imagen de usuario, ver ecuación 15, se procede a la obtención de la imagen promedio por medio de la ecuación 16.

$$Usu = \begin{bmatrix} usuario_1 & usuario_2 & \cdots & usuario_n \\ \vdots & \vdots & \ddots & \vdots \\ usuario_1 & usuario_2 & \cdots & usuario_n \end{bmatrix} \quad (15)$$

$$Med = \mathbf{mean}(Usu')' \quad (16)$$

Al obtener la media de los usuarios se restara la imagen promedio a cada una de las imágenes de usuarios, se realiza la sustracción por medio de la ecuación 17 y 18.

$$Usu = \begin{bmatrix} usuario_1 - Med & usuario_2 - Med & \cdots & usuario_n - Med \\ \vdots & \vdots & \ddots & \vdots \\ usuario_1 - Med & usuario_2 - Med & \cdots & usuario_n - Med \end{bmatrix} \quad (17)$$

$$Usu(i) = Usu(i) - Med \quad (18)$$

Con la matriz de Usuarios resultante de la resta de la media, se calcula la covarianza por medio de la ecuación 19.


$$L = Usu' * Usu \quad (19)$$

Una vez se calcula la covarianza se procede a la obtención de los eigenvectores y eigenvalores del grupo de imágenes los cuales se ordenaran de mayor a menor dependiendo de los eigenvalores, la obtención de los parámetros se realiza por medio de la ecuación 20.

$$[Vectores, Valores] = eig(L) \quad (20)$$

Con los eigenvectores se realiza la proyección general por medio de la ecuación 21, la cual constituye a la creación del sub-espacio ver figura 6.

Figura 64. Subespacio de los usuarios



Fuente: propia

$$Proy_{General} = Vectores' * Usu_{Media} \quad (21)$$

Donde Usu_{Media} es la matriz que contiene los datos de las imágenes menos la media de las imágenes.

Reconocimiento de un rostro, para llevar a cabo el reconocimiento se proyecta el $Vector_{Media}$ que es el resultado de la resta del vector columna (imagen de usuario) y la media de los rostros del sub-espacio, multiplicado por el eigenvector del sub-espacio por medio de la ecuación 22.

$$Proy_{Usuario} = V' * Vector_{Media} \quad (22)$$

Donde V es el vector que contiene los eigenvectores.

LOCALIZACIÓN DE LOS PUNTOS DE LOS OJOS, LA BOCA Y LA NARIZ

Para la identificación de género se identifican las posiciones de los ojos, la nariz y la boca, para ello se utilizan la técnica de Harris (detección de bordes) y el método de detección de ojos.


POSICION DE LOS OJOS Y LA NARIZ

Comenzando con el método de detección de ojos, La ubicación de la nariz está determinada desde la adquisición de la imagen y sus coordenadas están determinados en ' x ' por la componente ' x ' del punto medio y en ' y ' por posición del recuadro al momento de la adquisición de la imagen.

POSICION DE LA BOCA

La ubicación de la boca se realiza haciendo un corte en la sección de la boca figura 7.a, luego es tratada y acondicionarla figura 7.b para aplicarle la técnica de Harris y determinar la posición figura 7.c.

Figura 75 (a) recorte zona de la boca, (b) tratamiento a la imagen, (c) aplicación método de Harris




Fuente: propia

CALCULO DE DISTANCIAS

Con la detección de todos los puntos del rostro, se realiza una relación entre ellos para determinar las distancias necesarias para la identificación de género como se muestra en la figura 8.

Figura 86. Distancias propuestas para la identificación de género



Fuente: propia

Se determinan relaciones de proporción entre los puntos de la imagen, con los cuales se creará la matriz con la que se entrenará el clasificador neuronal inteligente con la finalidad de realizar la clasificación de género. El clasificador se entrenará con la matriz de clases tanto de hombres como de mujeres.

MATRIZ CARACTERÍSTICA DE USUARIO

La matriz característica del Usuario, es una matriz que está basada en la comparación de las distancias del usuario contra un promedio y la adición o sustracción de una desviación estándar, creando así una imagen matricial de cada usuario.

Con la matriz de Usuarios definida, se obtienen los vectores columna Promedio y Desviación estándar, los cuales son fundamentales para el desarrollo de la matriz característica, estos vectores están conformados por las filas formadas por las proporciones de las distancias obtenidas anteriormente (Ver figura 9).

Figura 97. Obtención de los vectores Promedio y Desviación estándar

Usuario(1) Usuario(2) Usuario(n)						
D1/	D1/	...	D1/	P1		Des1
D2/	D2/	...	D2/	P2		Des2
D3/	D3/	...	D3/	P3		Des3
D4/	D4/	...	D4/	P4	Desviacion estandar =	Des4
D5/	D5/	...	D5/	P5		Des5
D6/	D6/	...	D6/	P6		Des6
D7/	D7/	...	D7/	P7		Des7
42*n						42

Fuente: propia

Dejando claro la composición de la matriz, se llena con los valores iniciales y finales ya calculados, colocando en el intervalo cerrado $[i, f]$, todo lo comprendido entre estos valores será igual a cero '0' y lo que este por fuera con unos '1'.


De esta manera de imagen matricial, se representan los usuarios para el posterior análisis e identificación de género llevado a cabo con la red backpropagation.

ENTRENAMIENTO DE LA RED NEURONAL

La red neuronal a utilizar es la red backpropagation la cual está actuando como un clasificador inteligente para determinar el género del usuario, la estructura utilizada en la red se observa en la figura 10.

En el entrenamiento de la red, se utiliza el 70 % de los usuarios para el entrenamiento y el 30 % para la comprobación.

Figura 10. Estructura utilizada de la red back propagation

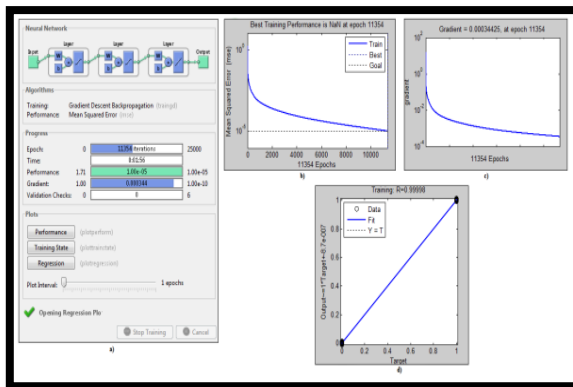


Fuente: propia

RESULTADO DEL ENTRENAMIENTO

El entrenamiento de la red tardó un minuto y cincuenta y seis segundos (01:56), le tomo 11354 épocas para superar el punto mínimo de error asignado, las características completas de la finalización del entrenamiento de la red se observa en la figura 11.


Figura 11. Resultado del entrenamiento de la red neuronal backpropagation, a) informe general del entrenamiento, b) recorrido del error, c) recorrido del gradiente, d) regresión lineal



Fuente: propia

La efectividad de la red se comprobó con la introducción del 30 % de usuarios de la base de datos, esta cantidad de usuarios no fueron utilizados para el entrenamiento de la red. Ver figura 12.

Figura 12. resultado del análisis con el método 2, a) porcentaje de detección análisis 1, b) porcentaje de detección análisis 2, c) porcentaje de detección análisis 3, d) porcentaje de detección análisis 4.



Fuente: propia

METODOLOGÍA PARA LAS APLICACIONES PCA Y MODELOS ACTIVOS

Para un desarrollo adecuado de las técnicas se sugieren los siguientes pasos:

1. Como paso general para un correcto trabajo de las técnicas, es indispensable definir los parámetros de entrada de los métodos. Parámetros como:
 - Distancia de la imagen.
 - Luminosidad de la imagen.
 - Tipo de cámara, resolución, tamaño de la foto, parámetros para el dispositivo de captura.
 - Formato de la imagen.
2. Una adecuada adecuación de la imagen capturada, eliminación de impurezas o datos que no se necesiten para un ideal resultado.
3. Realizar un estudio sobre las técnicas, para conocer los parámetros que se utilizan en cada una de ellas.

4. Para el PCA, es imprescindible la obtención de los parámetros como lo son:

- El cálculo de la covarianza.
- El cálculo de los eigenvectores.
- El cálculo de los eigenvalores.
- La obtención de la proyección en el subespacio.

5. Para el trabajo con Modelos activos, se describen ciertas características:


- Definir correctamente los parámetros básicos que utiliza el método para el desarrollo del mismo.
- Si el proceso lo permite, desarrollar una interacción infinita en la cual se modifiquen periódicamente los valores básicos del método.
- Una vez superada la detección de los puntos arrojados por el método, identificar los puntos de interés para el estudio a realizar.
- Se pueden definir sectores (cortes) para realizar el análisis y obtener un mejor desempeño de la técnica.

ANÁLISIS NO LINEAL DE COMPONENTES PRINCIPALES

La Reducción de dimensionalidad facilita en gran medida la clasificación de patrones. Varias técnicas, lineal y no lineal, se han propuesto y utilizado ampliamente para la reducción de dimensionalidad en los sistemas de reconocimiento de rostros. El Análisis de componentes principales (PCA) ha demostrado ser un método lineal simple y eficiente, mientras que muchos de los métodos no lineales como el núcleo PCA, se han propuesto recientemente. El análisis no lineal de componentes

principales (NLPCA) es comúnmente visto como una generalización no lineal de análisis estándar de componentes principales (PCA). Se generaliza los principales componentes de las líneas rectas a curvas (no lineal). Por lo tanto, el subespacio en el espacio de datos original que se describe por todos los componentes no lineales está también curvada. PCA no lineal se puede lograr mediante el uso de una red neuronal con una arquitectura auto-asociativa también conocido como autoencoder, red replicadora, cuello de botella o de la red de tipo reloj de arena, ver figura 13. Tal red neuronal auto-asociativa es un perceptrón multicapa que realiza una asignación de identidad, lo que significa que la salida de la red es necesaria que sea idéntica a la entrada. Sin embargo, en el medio de la red es una capa que funciona como un cuello de botella en la que se aplica una reducción de la dimensión de los datos. Este cuello de botella-capas proporciona los valores de los componentes deseados (resultados). Hemos desarrollado un algoritmo simple que utiliza esta reducción de dimensionalidad no lineal para el reconocimiento facial. Este enfoque no requiere la detección de cualquier punto de referencia y se puede utilizar para aplicaciones en tiempo real.

Figura13. Auto-associative neural network (Autoencoder)




Fuente: propia

ANÁLISIS DE COMPONENTES INDEPENDIENTES

En una tarea, como el reconocimiento de Rostros, mucha de la información importante puede estar contenidos en las relaciones de orden superior entre los píxeles de la imagen. Ver figura 14. Un número de algoritmos de reconocimiento de la cara pueden emplear el análisis de componentes principales (PCA), que se basa en las estadísticas de segundo orden de la imagen de conjunto, y no se ocupa de alto orden de dependencias estadísticas tales como las relaciones entre tres o más píxeles. El Análisis de componentes independientes (ICA) es una generalización de PCA que separa los momentos de mayor orden de la entrada en adición a los momentos de segundo orden. ICA se realizó en un conjunto de imágenes del Rostro por un algoritmo de aprendizaje no supervisado que deriva del principio de la transferencia de información óptima a través de las neuronas sigmoideal. El algoritmo maximiza la información mutua entre la entrada y la salida, que produce resultados estadísticamente independientes bajo ciertas condiciones. La representación ICA fue superior a las representaciones basadas en el análisis de componentes principales para el reconocimiento de rostros a través de sesiones y los cambios en la expresión.

Figura 14. ICA descomposición



Fuente: propia

I. APLICACIONES

Toda nuestra investigación ha sido programada e incorporada en un GUIDE programado en Matlab, en la figura 15 se muestra el GUIDE resultante.

Figura 15. ICA descomposición



Fuente: propia

Nuestra investigación ha permitido mediante las hibridación de los métodos y técnicas para el reconocimiento de patrones para el caso de estudio de reconocimiento de rostros en conjunto a técnicas de inteligencia artificial como las redes neuronales obtener otras aplicaciones como lo es el uso de los modelos activos para la determinación de patrones del estado emocional rostro capturado a fin de mediante el uso de un clasificador inteligente reconocer que emoción representa, figura 16.

Figura 16. ICA descomposición



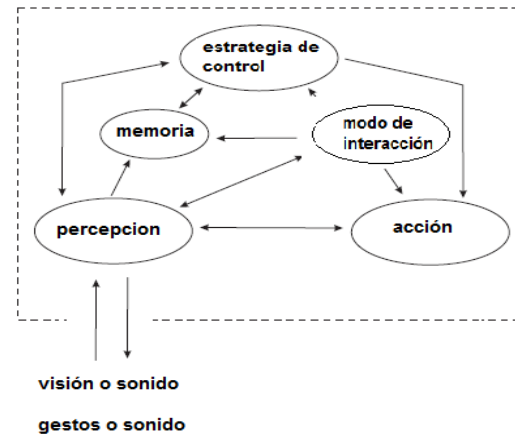
Fuente: propia

Una de las aplicaciones más relevantes del trabajo realizado consiste en proporcionar las entradas necesarias a los sistemas de control de *robots socialmente interactivos*, dado que estos son agentes robóticos en los que la interacción social es el papel más importante de su funcionamiento y por tal vital para cumplir con la motivación para la cual fueron creados.

Para cumplir dicho objetivos de interacción social el Robot deben contar con los mecanismos de sensórica y algoritmos de interpretación del mundo que abstraigan las características comportamentales que le permitan interactuar con agentes humanos [7].

El propósito final como contribución al sistema de control de robots socialmente interactivos ver figura 17, consistirá en robustecer su estructura de percepción dado que el modelo de control de este tipo de robot depende de la captación del mundo en la cual el sistema de reconocimiento de rostros mediante la hibridación de técnicas de reconocimientos de patrones, visión artificial e inteligencia artificial proveería una mejor definición del mundo o de los usuarios con los que interactúan a fin de obtener una mayor eficiencia en la estrategia de control y en el establecimiento del modo de interacción en respuesta de la percepción de manera de mantener el propósito de interacción social del robot.

Figura 17. Esquema de un sistema de visión por computador tradicional



Fuente: propia

Referencias bibliográficas

- [1] Iain Matthews and Simon Baker, Active Appearance Models Revisited, The Robotics Institute Carnegie Mellon University, 2002.
- [2] Alexander Ocsa M., Alexander Rodriguez V., Herbert Chuctaya H., Gabriel Humpire M. Reconocimiento de Rostros mediante Puntos, Simposio Peruano de computación gráfica y procesamiento de imágenes, 2008.
- [3] Chris Harris & Mike Stephens, a combined corner and edge detector, the Plessey company plc. 1988.
- [4] Mohammadreza Ramezanpour, Mohamad Ali Azimi, Mohammad Rahmati, a new method for eye detection in color image.
- [5] Gregory Shakhnarovich y Baback Moghaddam, face recognition in subspaces, Handbook of Face Recognition, Springer-Verlag, 2004, Cap7.

[6] Juan Carlos Moctezuma, Neural Network toolbox de Matlab, ciencias computacionales INAOE, septiembre 2006.

[7] FONG, Terrence; NOURBAKHSH, Illah; DAUTENHAHN, Kerstin. A Survey of Socially Interactive Robots: Concepts, Design, and Applications. Robotics and Autonomous Systems 42. 2003. Pag 143–166.